

Control estadístico de procesos con dinámica: revisión del estado del arte y perspectivas de futuro

por
ALBERTO FERRER

Dpto. Estadística e Investigación Operativa Aplicadas y Calidad
Universidad Politécnica de Valencia

RESUMEN

En este trabajo se presenta una revisión bibliográfica del estado del arte en la aplicación del Control Estadístico de Procesos (*Statistical Process Control*, SPC) en procesos con dinámica, típicos en los modernos entornos altamente automatizados tanto de la industria de piezas, como de la de procesos, donde la correlación entre las observaciones forma parte del sistema de causas comunes de variabilidad. Se presenta en primer lugar una revisión de las estrategias de monitorización desarrolladas para adaptar los gráficos de control estándar a procesos con inercia. Seguidamente se introduce la estrategia combinada ESPC (*Engineering Statistical Process Control*), integración del SPC con la teoría de control de procesos (*Engineering Process Control*, EPC), que aprovecha la información valiosa que proporciona la propia dinámica de los procesos, junto con la existencia de variables de control, fácilmente manipulables, para mejorar el control de los procesos. Se presentan diversas aplicaciones reales exitosas de la estrategia combinada ESPC y se apuntan algunas líneas de investigación abiertas.

Palabras clave: Autocorrelación; Controladores con restricciones; Gráficos de control; Modelos ARIMAX; Monitorización estadística de procesos; Regulación de procesos.

Clasificación AMS: 62M10; 62N10; 93A25; 93B30; 93B52

1. INTRODUCCIÓN

El Control Estadístico de Procesos (*Statistical Process Control*, SPC), cuyos fundamentos son establecidos por Walter Shewhart en la década de los años 1930 (Shewhart 1931) descansa sobre un concepto esencial: el de la diferenciación entre causas *comunes* y causas *especiales* de variabilidad. Las primeras, que son aquellas que están permanentemente presentes en cualquier proceso como consecuencia de cómo ha sido diseñado y de cómo es operado normalmente, producen en sus resultados una pauta de variabilidad estable y predecible en el tiempo que configura lo que se denomina proceso *bajo control estadístico* y define la capacidad del mismo. Las causas especiales, por su parte, tienen un carácter esporádico y puntual, estando asociadas a anomalías no previstas que provocan las denominadas *salidas de control* del proceso.

El objetivo del SPC es el de establecer un sistema de observación, permanente e inteligente, que detecte precozmente la aparición de causas especiales de variabilidad y ayude a identificar su origen, con el fin último de eliminarlas del proceso y de tomar medidas que eviten su reaparición en el futuro (Romero 2000). Su fundamento es la toma periódica de muestras y la representación gráfica de estadísticos adecuadamente elegidos para monitorizar eficientemente los parámetros clave del proceso, y que actúan como señales de aviso de las salidas de control del proceso. Estos gráficos de control, bien utilizados, constituyen una herramienta de mejora muy útil y poderosa por diferentes motivos: implican a operarios, encargados, técnicos y directivos en la gestión de la calidad; evitan tanto los problemas de sobreajuste o infraajuste de los procesos; permiten diferenciar entre problemas puntuales, que pueden resolverse mediante simples actuaciones locales, y problemas asociados a las causas comunes de variabilidad, cuya resolución exige actuaciones sobre el sistema que deben plantearse desde la Dirección; y posibilitan establecer la capacidad real del proceso.

Entre los métodos del SPC, destacan los gráficos de control propuestos por Shewhart (Shewhart 1931) y otros de desarrollo posterior, como los gráficos de sumas acumuladas (CUSUM) (Page 1954, 1961; Barnard 1959), o los de medias móviles y los gráficos EWMA (*Exponentially Weighted Moving Averages*) (Roberts 1959; Hunter 1986). En el empleo y diseño de estos gráficos se asume que las

observaciones son estadísticamente independientes, siendo ésta una hipótesis clave en las propiedades estadísticas de estos gráficos. Sin embargo, esta suposición es frecuentemente violada en muchos procesos industriales modernos. Así, aunque en la industria de piezas (automóvil, electrónica, etc.) tradicionalmente esta hipótesis ha sido razonable en la práctica, por lo que los gráficos de control han resultado excelentes herramientas para mantener los procesos bajo control estadístico, sin embargo, con el desarrollo explosivo de las nuevas tecnologías que facilitan la automatización de los procesos, es frecuente encontrar dispositivos que proporcionan en un entorno CIM (*Computer Integrated Manufacturing*) información sobre cada pieza fabricada, o sobre parámetros operativos del proceso (v.g. presión del circuito hidráulico del brazo del robot que debe taladrar la pieza), no pudiendo aceptarse como válida la hipótesis de independencia en los datos (Keats y Hubele 1991; Keats y Montgomery 1991). Esto mismo ocurre, por otra parte, en las industrias de procesos con procedimientos de fabricación en continuo o por lotes, típicos de sectores como el petroquímico o el farmacéutico, donde es frecuente la existencia de autocorrelaciones entre medidas sucesivas.

La presencia de correlación no debe interpretarse como una causa especial de variabilidad, sino como parte del sistema de causas comunes intrínseco al proceso en cuestión, consecuencia de la presencia de elementos inerciales como flujo de materias primas, tanques de almacenamiento, reactores, reflujos, condiciones ambientales, etc. con tiempos de residencia o dinámicas (inercias) mayores que la frecuencia de muestreo. Por ejemplo, si en un proceso de fabricación de polietileno mediante un reactor en lazo, las moléculas de etileno tienen un tiempo de residencia en el reactor de unas cuatro horas y se toma una muestra del reactor cada hora, hay moléculas que han coexistido en el reactor en varias tomas de muestra, por lo que es esperable encontrar correlaciones entre muestras consecutivas (Capilla *et al.* 1999). En general todos los procedimientos de fabricación presentan cierta inercia frente a la acción de parámetros ambientales, el cambio de materias primas o al ajuste de sus condiciones operativas, por lo que un aumento de la frecuencia de muestreo puede llegar a generar la aparición de autocorrelación entre observaciones cercanas en el tiempo.

Tras esta introducción, el trabajo se estructura como sigue: en la sección siguiente se revisa el comportamiento de los gráficos de control en presencia de correlaciones y las soluciones planteadas para mejorar sus propiedades estadísticas; en la tercera sección se introduce la estrategia ESPC, integración del control estadístico con el control automático de procesos; en la última sección se presentan algunas conclusiones y líneas abiertas de investigación en estos temas.

2. GRÁFICOS DE CONTROL CON DATOS CORRELACIONADOS

Diversos autores han estudiado el comportamiento de los gráficos de control en presencia de autocorrelación (Bagshaw y Johnson 1975; Capilla 1991; Constable y Yen 1991; Goldsmith y Whitfield 1961; Harris y Ross 1991; Johnson y Bagshaw 1974; Vasilopoulos y Stamboulis 1978).

En los gráficos de medias móviles, CUSUM y EWMA, la correlación positiva (la más frecuente en la práctica industrial) disminuye notablemente el ARL bajo control (*in-control Average Run Length*, o número medio de muestras entre dos falsas salidas de control consecutivas), lo que se traduce en la práctica en un mayor número de falsas alarmas. Esto provoca la sensación de que el proceso está permanentemente fuera de control, lo que no se corresponde con la realidad y suele conducir a un sobreajuste del proceso y al abandono posterior de su uso como herramienta de mejora. La justificación de estos resultados se encuentra en la modificación que sufre la varianza del estadístico que se grafica cuando se calcula a partir de observaciones correlacionadas. Con correlación positiva la varianza es mayor que la que se asume en la construcción y diseño del gráfico (v.g. para un proceso AR(1) con $\phi=0.7$, la desviación típica de la media muestral con tamaño de agrupamiento $n=5$ es casi el doble que en el caso independiente, σ/\sqrt{n}). Adicionalmente, la aplicación de recorridos móviles para estimar la desviación típica mediante la expresión $R/d_2(n)$ subestima la σ real de la población, puesto que las diferencias entre medidas consecutivas son, en general, más pequeñas que en el caso de independencia. Esto provoca una subestimación importante de la amplitud real de los límites de control. Junto con esta frecuencia elevada de falsas alarmas, los gráficos de control también pueden mostrar escasa potencia para detectar ciertas salidas de control del proceso (v.g. con correlación positiva, un salto brusco entre dos observaciones consecutivas, que con datos independientes no tendría por qué considerarse una señal de falta de control, puede indicar la aparición de una causa especial de variabilidad no detectada por el gráfico de control).

El fenómeno contrario se produce en el caso de que la correlación sea negativa. En este caso la sobrestimación de la varianza real provoca unos límites de control innecesariamente amplios que, aunque bajo control reducen el porcentaje de falsas alarmas, merman la sensibilidad de los gráficos para detectar cambios reales en el proceso (aumentan el ARL fuera de control, es decir, el número medio de muestras desde que se produce la salida de control hasta que se detecta).

Este mal comportamiento de los gráficos de control estándar en presencia de correlación ha motivado en los últimos veinte años un gran interés científico por

desarrollar nuevas estrategias de monitorización eficientes en procesos con dinámica, que permitan detectar la presencia de causas especiales de variabilidad cuando la autocorrelación en los datos forma parte de las causas comunes, pero eliminando los problemas de frecuentes falsas alarmas o escasa potencia que plantean los gráficos de control tradicionales en este contexto.

Hasta la fecha se han propuesto varias soluciones. Una consiste en la modificación de los parámetros de diseño y las reglas de interpretación de los gráficos de control estándar (Shewhart, CUSUM y EWMA) para compensar el efecto de la correlación sobre sus propiedades estadísticas (Alwan 1992; VanBrackle y Reynolds 1997; Vasilopoulos y Stamboulis 1978). Si el nivel de autocorrelación no es alto, este método puede funcionar bien en la práctica.

Otra posible solución (Berthouex *et al.* 1978) consiste en filtrar la serie de observaciones mediante el modelo ARIMA adecuado (Box *et al.* 1994) y a continuación llevar un gráfico de control de la serie de residuos del modelo. Si éste está bien ajustado, los residuos o errores de predicción a un paso (diferencia entre el valor observado en el instante t y el predicho por el modelo en $t-1$) están incorrelacionados, por lo que pueden utilizarse los gráficos de control estándar. Alwan y Roberts (1988) proponen llevar en paralelo al gráfico de control de los residuos, otro gráfico, sin incluir límites de control, de las predicciones del modelo. El primer gráfico sirve para detectar la presencia de causas especiales de variabilidad, mientras que el segundo refleja las causas comunes, grafica la trayectoria *suavizada* del proceso y puede facilitar la interpretación de las salidas de control detectadas en el gráfico de los residuos. También puede añadirse en este segundo gráfico las observaciones originales con el fin de tener información de lo que está pasando en cada instante en el proceso. Montgomery (2001) y Montgomery y Mastrangelo (1991) sugieren estimar la predicción aplicando un alisado exponencial, EWMA, a la serie original. El procedimiento en este caso también consiste en llevar dos gráficos en paralelo. Uno es el gráfico de control de los residuos del modelo (errores de predicción a un paso). El otro es un gráfico de la serie original sin límites de control, en el que se incluyen las predicciones EWMA con sus límites de control correspondientes. Teóricamente el EWMA es la predicción óptima a un paso de un modelo IMA (1,1) (Box *et al.* 1994), por lo que la propuesta de Montgomery sólo debe aplicarse cuando el modelo IMA(1,1) ajuste bien los datos observados. Sin embargo, en la práctica este modelo puede considerarse razonable en muchos procesos con correlación positiva y donde la media no fluctúe demasiado rápidamente. En este sentido algunos autores (Box y Kramer 1992; Box y Luceño 1997; MacGregor 1988) consideran que el modelo IMA(1,1) es en procesos continuos correlacionados, el equivalente al modelo Normal tradicionalmente utilizado en las industrias de piezas con baja frecuencia de muestreo relativa a los elementos inerciales y, por tanto, con observaciones independientes.

Recientemente, han aparecido en la bibliografía muchos trabajos de investigación sobre las propiedades estadísticas de los gráficos de los residuos del modelo ARIMA ajustado, comparándolas con las de los gráficos tradicionales en presencia de correlación (Faltin *et al.* 1997; Harris y Ross 1991; Lin y Adams 1996; Lu y Reynolds 1999a y 1999b; Padgett *et al.* 1992; Runger *et al.* 1995; Superville y Adams 1994; Vander Wiel 1996; Wardell *et al.* 1994; Zhang 1998). El resultado de estas investigaciones muestra que no hay una combinación de gráficos que tenga un comportamiento óptimo en un amplio rango de situaciones. En general, los gráficos CUSUM o EWMA de los residuos muestran un comportamiento mejor que los gráficos Shewhart para detectar ciertos cambios en la media de procesos con inercia. Sin embargo, en presencia de una elevada correlación positiva, todos los gráficos de residuos manifiestan una clara incapacidad para detectar rápidamente cambios sostenidos en la media del proceso, puesto que su ARL fuera de control es muy elevado.

Una tercera solución al problema del SPC con datos correlacionados ha sido propuesta recientemente por Apley y Tsung (2002), y constituye una mejora del método propuesto por Alwan y Alwan (1994). Consiste en construir en cada instante t , a partir de la serie univariante de datos autocorrelacionados, un vector multivariante de dimensión p constituido por una ventana móvil de p observaciones consecutivas $\mathbf{X}_t = \{x_{t-p+1}, x_{t-p+2}, \dots, x_t\}$ a partir del cual graficar el estadístico T^2 -Hotelling:

$$T_t^2 = (\mathbf{X}_t - \mu_0)' \mathbf{V}^{-1} (\mathbf{X}_t - \mu_0),$$

donde \mathbf{V}^{-1} es la matriz de covarianzas del vector \mathbf{X}_t . Apley y Tsung (2002) denominan este gráfico como T^2 autorregresivo y comparan el ARL de este gráfico con el de los gráficos CUSUM y Shewhart de los residuos suponiendo diferentes modelos ARMA(1,1). El gráfico T^2 autorregresivo funciona mejor que los gráficos de los residuos en la rápida detección de cambios moderados y grandes de la media del proceso, y es más robusto frente al incremento de falsas alarmas que se producen cuando existen errores de especificación o estimación en el modelo.

3. INTEGRACIÓN DEL CONTROL ESTADÍSTICO DE PROCESOS (SPC) CON EL CONTROL INGENIERIL DE PROCESOS (EPC): ENFOQUE ESPC

3.1. Concepto del ESPC

Las soluciones descritas en el apartado anterior para aplicar el SPC en procesos con inercia, diseñadas con el único fin de detectar causas especiales de variabilidad, desaprovechan la información valiosa que proporciona la estructura de

autocorrelaciones presente en los datos. En efecto, en procesos con dinámica, los valores observados contienen información que permite predecir la evolución futura del proceso; información que, si se dispone de *variables compensatorias* fáciles de manipular, puede aprovecharse para tomar acciones que mejoren dicha evolución futura, minimizando la variabilidad predecible respecto del valor óptimo y mejorando de forma continua la calidad del producto. Esto es especialmente necesario en procesos no estacionarios en media, muy frecuentes en procesos continuos, puesto que deben ser intervenidos para mantener el *output* en torno al valor objetivo.

La filosofía clásica del SPC: “*no actuar a no ser que el proceso se salga de control*”, siendo razonable cuando existe un alto coste asociado a la realización del ajuste (puesto que esto puede suponer la paralización de la máquina, cambio de herramienta, reducción de la productividad, etc.), lo cual ha venido siendo frecuente en la industria de piezas, no lo es tanto cuando el coste de ajustar el proceso es prácticamente despreciable comparado con el coste de no fabricar en el objetivo, como suele ocurrir en muchos procesos continuos. En esta situación lo más adecuado no es ajustar el proceso sólo cuando no esté bajo control, sino hacerlo continuamente mediante ajustes en variables compensatorias, de forma que se minimice la variabilidad del *output* en torno al valor objetivo, utilizando las técnicas de regulación automática (control *feedback-feedforward*) en lo que se conoce como estrategia de Control Automático de Procesos (*Automatic Process Control*, APC), también llamada Control Ingenieril de Procesos (*Engineering Process Control*, EPC).

El control *feedforward* se utiliza cuando las perturbaciones o ruidos a los que está sometido el sistema se pueden medir directamente en su origen (ruidos identificables; v.g. propiedades de materias primas) y se puede actuar ajustando una variable compensatoria para contrarrestar su efecto sobre el *output*. Cuando alternativa, o adicionalmente, se usan las desviaciones del *output* respecto a su nominal (ruido residual o no identificable) para calcular los ajustes compensatorios, aparece el control *feedback*, o *feedforward-feedback*, respectivamente. Las acciones de control pueden ejecutarse manualmente o mediante controladores automáticos, por ejemplo del tipo PID (Proporcional-Integral-Derivativo) muy utilizados en la industria para controlar parámetros de proceso (v.g., temperaturas en reactores o en circuitos de calefacción-refrigeración, etc.). Mediante estos algoritmos de control se transfiere la variabilidad del *output*, que es la que genera problemas de calidad, al *input* (variable de ajuste), cuya manipulación no supone prácticamente coste en muchos procesos continuos reales. La ventaja que ofrece este tipo de control es que utiliza la información existente en los datos del pasado para optimizar la evolución futura del proceso.

La utilización de la filosofía SPC para *ajustar* procesos con dinámica se ha mostrado altamente ineficiente, generando un rechazo hacia esta estrategia por parte de los ingenieros de procesos (Capilla *et al.* 1999; Hoerl y Palm 1997). Por otra parte, una crítica frecuente que se suele hacer a los enfoques EPC es que en muchas ocasiones las acciones de control se basan en reglas empíricas no adecuadas al proceso concreto, lo que conduce a sobreajustes o infraajustes del mismo. También se critica que al compensar la variabilidad (los controladores actúan como “cajas negras” que contrarrestan el efecto de las perturbaciones que desvían la característica de calidad de su valor objetivo), en vez de eliminar sus causas, el EPC enmascara información que podría utilizarse para mejorar el proceso permanentemente.

Aunque el SPC y el EPC se originan en sectores industriales diferentes: la industria de piezas y la de procesos continuos, respectivamente, hoy día las diferencias entre los procesos de ambos tipos de industrias comienzan a difuminarse, debido fundamentalmente a la automatización y al desarrollo espectacular de las tecnologías de captación y de transmisión de información. Dada la frecuencia con que en los modernos procesos industriales se presentan fenómenos dinámicos que desestabilizan los procesos y hacen necesario recurrir a algoritmos de control para tratar de estabilizar su media, es indudable el interés que tiene esta nueva aproximación al problema del control *on-line* de procesos con inercia.

El EPC y el SPC son realmente dos estrategias complementarias para la mejora de la calidad que, sin embargo, hasta hace unos años se han venido desarrollando de forma completamente independiente y en algunos casos han podido incluso considerarse como antagónicas. Una de las razones de este antagonismo es que ambas estrategias utilizan el término *control* para referirse a aspectos tan dispares como son la *regulación* y la *monitorización* de procesos. Las técnicas de regulación (EPC) describen métodos mediante los cuales se fuerza al proceso a seguir una política determinada mediante ajustes en variables compensatorias fácilmente manipulables. Por otro lado, la monitorización (SPC) se refiere al método mediante el cual se implanta un sistema de información permanente e inteligente de la evolución del proceso a lo largo del tiempo para detectar precozmente cualquier anomalía que pueda ocurrir, y ayudar en la identificación de sus causas, con el fin último de eliminarlas y tomar medidas para evitar su reaparición en el futuro (o bien, si fueran favorables, que las incorporen permanentemente en el proceso).

A la hora de determinar la estrategia de control adecuada es necesario distinguir si el objetivo es el *contraste de la hipótesis* estadística de que el proceso es estable (está sometido sólo a causas comunes de variabilidad) y la *detección de señales* en procesos contaminados con ruido (objetivos típicos de la estrategia de monitorización), o si lo que se pretende es la *estimación* estadística del valor de la perturba-

ción actual que necesita ser compensada por el algoritmo de control (objetivo de la estrategia de regulación).

Algunos trabajos recientes (Box y Kramer 1992; Box *et al.* 1997; Box y Luceño 1997a; Ferrer *et al.* 2000; Janakiram y Keats 1998; MacGregor 1988, 1991; MacGregor y Harris 1990; Messina *et al.* 1996; Montgomery *et al.* 1994; Palm 1990; Woodall y Montgomery 1999) proponen en estos contextos la integración de ambos enfoques SPC y EPC, tratando de aprovechar las potencialidades de cada uno de ellos. Faltin *et al.* (1993), Tucker *et al.* (1993) y Vander Wiel *et al.* (1992) denominan a esta nueva estrategia Control Estadístico de Procesos Algorítmico (*Algorithmic Statistical Process Control*, ASPC). Por su parte, Nembhard y Mastrangelo (1998) la denominan Control de Procesos Integrado (*Integrated Process Control*, IPC). Capilla *et al.* (1999) y Ferrer *et al.* (1998) desarrollan en un proceso industrial petroquímico la nueva estrategia ESPC aplicada al control del índice de fluidez de un polímero mediante ajustes en la temperatura del reactor. Por su parte, Ferrer *et al.* (2000) discuten los beneficios del enfoque integrado EPC/SPC en el control de la homogeneidad del calibre de azulejos mediante ajustes en los perfiles de temperaturas del horno de cocción de una empresa azulejera.


La nueva estrategia ESPC (integración del EPC con el SPC) nace con el propósito de ser una herramienta de mejora de la calidad que reduce la variabilidad predecible (debida a las causas comunes) en las características de calidad mediante el control *feedback-feedforward*, e incorpora un esquema de monitorización global del sistema regulado para detectar y ayudar en la eliminación de problemas no predecibles en el proceso (provocados por las causas especiales). La componente EPC de este enfoque estudia la dinámica de las relaciones entre una o más variables *output* y una o varias variables *input*, para obtener la ecuación de control óptimo (Box *et al.* 1994; Isermann 1981) que permite compensar el efecto previsible de las causas comunes de variabilidad. Por otra parte, los gráficos de control SPC permiten reducir la dispersión a largo plazo y contribuir a la mejora continua de los procesos mediante la detección e identificación de causas especiales de variabilidad, implantando un sistema de monitorización permanente del proceso. La estrategia ESPC incorpora las ideas de la Teoría del Control con las del SPC intentando reducir tanto la variabilidad a corto como a largo plazo, sustituyendo las consignas de “ajustar continuamente” (EPC) o “no actuar a no ser que el proceso se salga de control” (SPC), por la de “ajustar óptimamente y monitorizar el sistema regulado” (ESPC).

3.2. Modelos ARMAX y algoritmos de control

Una de las cuestiones clave en el desarrollo de la estrategia ESPC es el diseño del controlador a utilizar. El algoritmo de control óptimo (Box *et al.* 1994) depende de la estructura de la función de transferencia dinámica entre el *input* y el *output*, $H(B)$, y de la naturaleza de las perturbaciones aleatorias N_t (modelo ARIMA del ruido, $\phi(B)\nabla^d N_t = \theta(B)a_t$, siendo a_t un proceso estocástico de ruido blanco) que modelizan el sistema de causas comunes que determina el proceso en cuestión, es decir del modelo ARMAX:

$$Y_t = \xi_t + N_t = H(B)X_t + \frac{\theta(B)}{\phi(B)\nabla^d} a_t$$

que puede representarse esquemáticamente como:



donde Y_t y X_t son, respectivamente, las desviaciones de la característica de calidad (*output*) y de una variable de control manipulable (*input*) respecto a sus respectivos nominales. La naturaleza de los filtros $H(B)$ y $\frac{\theta(B)}{\phi(B)\nabla^d}$ depende, a su vez, de la dinámica del proceso relativa a la frecuencia de muestreo.

Las funciones de transferencia del tipo:

$$Y_t = (gB)X_t = gX_{t-1} \quad [1]$$

se denominan de *ganancia pura*, y definen los sistemas en los que todo el cambio en el *output* Y inducido por un cambio sostenido en el *input* X se produce tras un solo intervalo de tiempo. Este modelo es muy frecuente en las industrias de piezas donde, tras ajustar una máquina, el efecto se transmite inmediatamente a la siguiente pieza producida. En las industrias de procesos este modelo también puede ser válido si el intervalo de muestreo es suficientemente grande (es decir, baja frecuencia de muestreo) relativo a la inercia o tiempo de residencia del proceso, lo que suele ocurrir cuando el valor de la característica de calidad se obtiene tras costosas (por cuestiones de tiempo y/o dinero) y, por tanto, infrecuentes determinaciones analíticas en laboratorio.

Sin embargo, cuando el intervalo de muestreo es suficientemente pequeño como para que los efectos transitorios o dinámicos cobren importancia, la función de transferencia se modeliza mejor a partir de la expresión:

$$Y_t = \frac{w_s(B)B^f}{\delta_r(B)} X_t$$

donde $w_s(B)$ y $\delta_r(B)$ son dos polinomios en el operador B , y f es el retardo del sistema (número de intervalos de tiempo completos que tarda en aparecer en el *output* el efecto del cambio en el *input*). De entre todos estos modelos, la función de transferencia de *primer orden* expresada como:

$$Y_t = \frac{w_0 B^f}{1 - \delta B} X_t \quad [2]$$

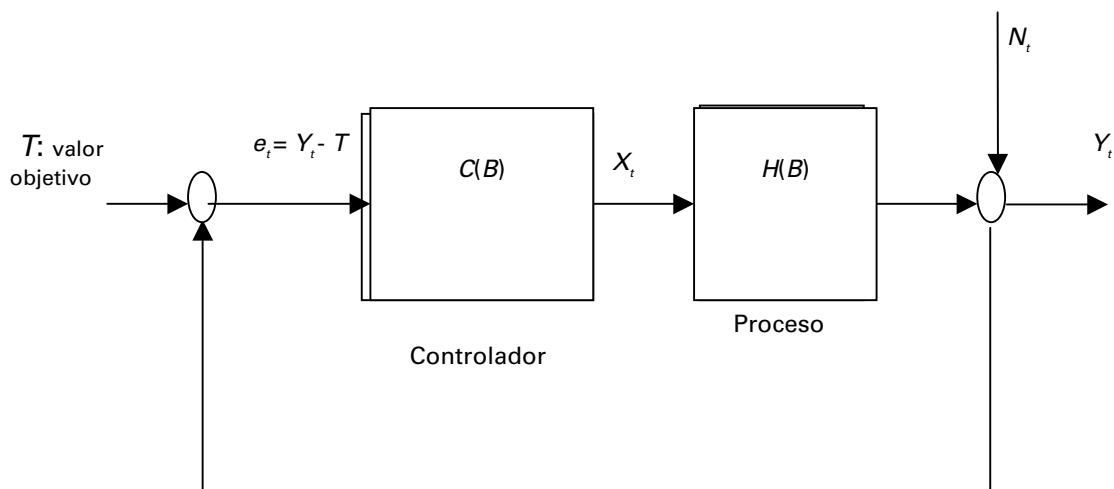
constituye una aproximación razonable para caracterizar el comportamiento dinámico de muchos procesos industriales reales (Box y Kramer 1992; MacGregor 1988).

Respecto al ruido N_t pueden considerarse modelos de perturbaciones estocásticas estacionarios del tipo ARMA, o también no estacionarios del tipo ARIMA. En modelos estacionarios, a medida que va aumentando el intervalo de muestreo, la autocorrelación va perdiendo fuerza, llegándose en el límite a un proceso de ruido blanco $N_t = a_t$ (observaciones independientes e idénticamente distribuidas), que es la hipótesis clásica del SPC tradicional. Por otra parte, los distintos modelos de ruido no estacionarios, a medida que el intervalo de muestreo aumenta, tienden todos al modelo límite IMA(1,1)

$$\nabla N_t = (1 - \theta B)a_t \quad [3]$$

Esta es una de las razones por las cuales en características de calidad de procesos no estacionarios obtenidas tras infrecuentes determinaciones analíticas en laboratorio, el modelo IMA es muy usado en la práctica del SPC, y sus predicciones EWMA suelen dar muy buenos resultados (MacGregor 1988).

Como ya se ha comentado antes, el objetivo del EPC es optimizar las acciones de control respecto a un criterio preestablecido. El esquema general de un proceso regulado puede representarse como:



Los esquemas óptimos a menudo tienen en cuenta diversos aspectos como:

- a) costes asociados a las desviaciones del *output* respecto a su nominal,
- b) costes debidos a las propias acciones de control tales como ajustar el proceso, muestrear, consumir más o menos energía, etc. (Box y Kramer 1992).

En muchos procesos industriales continuos el coste de no fabricar en el objetivo es muy superior al resto de costes, por lo que es el único que se suele considerar en la optimización de las acciones de control. Suponiendo, además, que este coste es proporcional al cuadrado de las desviaciones del *output* frente al nominal T:

$$\text{Coste} = k(Y-T)^2$$

minimizar dicho coste es equivalente a minimizar el error cuadrático medio, por lo que los algoritmos de control diseñados para minimizar esta función objetivo:

$$\min. E(Y_{t+1}-T)^2 = \min. [\sigma^2(Y_{t+1}) + (\text{sesgo}^2)] = \min. (Y_{t+f/t}^* - T)^2 \quad [4]$$

se denominan controladores de error cuadrático medio mínimo (MECM) o en terminología de control, controladores de mínima "varianza". Estos esquemas, en cada instante de tiempo t , determinan el ajuste del *input* de forma que la predicción de mínima varianza a f pasos del *output* hecha en t , $Y_{t+f/t}^*$ (Box *et al.* 1994), coincida con su nominal T .

En el caso en que la función de transferencia no refleje dinámica, es decir pueda expresarse como un modelo de respuesta rápida o ganancia pura (expresión [1]), el controlador de mínima varianza es:

$$X_t = -\frac{1}{g} N_{t+1/t}^* \quad [5]$$

donde $N_{t+1/t}^*$ es la predicción de mínima varianza de las perturbaciones en $t+1$, hecha en el instante t . Por tanto, las acciones de control dependen del modelo de las perturbaciones N_t .

Suponiendo un modelo estacionario ARMA(1,1):

$$(1 - \phi B)N_t = (1 - \theta B)a_t \quad [6]$$

entonces se obtiene que el controlador de mínima varianza es:

$$X_t = -\frac{\phi - \theta}{g} \sum_{i=0}^t \phi^i e_{t-i} \quad [7]$$

siendo $e_t = Y_t - T$, la desviación del *output* respecto a su nominal. Esta es la ecuación de un controlador integral con pesos exponencialmente decrecientes (puesto que $|\phi| < 1$).

Si se considera que el ruido sigue un modelo no estacionario IMA(1,1) (expresión (3)), el controlador de mínima varianza se expresa como:

$$X_t = -\frac{1 - \theta}{g} \sum_{i=0}^t e_i \quad [8]$$

que es la ecuación de un controlador integral puro, muy utilizado en industrias de procesos para regular caudales en sistemas con respuestas rápidas contaminados con perturbaciones no estacionarias (MacGregor 1988).

En el caso en que la dinámica del proceso sea importante y pueda modelarse mediante una función de respuesta de primer orden (expresión [2]) con $f=1$ (lo que

indica que un cambio en el *input* comienza a manifestarse en el *output* al instante siguiente), el controlador de mínima varianza es:

$$X_t = -\frac{(1-\delta B)}{w_0} N_{t+1/t}^* \quad [9]$$

y suponiendo que la perturbación sigue un modelo IMA(1,1) (expresión [3]), el controlador de mínima varianza es:

$$X_t = -\frac{(1-\theta)\delta}{w_0} e_t - \frac{(1-\theta)(1-\delta)}{w_0} \sum_{i=0}^t e_i \quad [10]$$

que es la ecuación de un controlador proporcional-integral (PI), uno de los más utilizados en las industrias de procesos.

Aunque estos controladores de mínima varianza son los óptimos desde el punto de vista de la minimización global de costes, pueden no ser los más adecuados en la práctica, debido a varias causas. La primera es que pueden requerir drásticas acciones de control que, o bien exceden los límites físicos de rango de los equipos de instrumentación, o pueden afectar otras respuestas, por lo que en muchos casos no son aceptadas por los operarios del proceso. Otra limitación es que no son robustos a errores en la modelización, ya que su funcionamiento y estabilidad dependen mucho de la precisión con que se ha estimado el modelo ARMAX (Box *et al.* 1994; Bergh y MacGregor 1987; Harris y MacGregor 1987). Adicionalmente, este tipo de controladores no puede utilizarse en sistemas de fase no mínima (no invertibles), pues no serían viables ya que para cancelar una desviación del *output* en t provocarían acciones de control cada vez más grandes en los instantes de ajuste siguientes (Capilla *et al.* 1999; Harris, MacGregor y Wright 1980).

Para tratar de solucionar este problema se pueden diseñar algoritmos de control en los que, a costa de incrementar el error cuadrático medio (ECM) del *output* (respecto a la opción de mínima varianza), se requieren ajustes de menor magnitud en las acciones de control. Estos algoritmos de control alternativos a los de mínima varianza se obtienen modificando la función objetivo a minimizar [4], por otra en la que intervienen tanto las desviaciones del *output* como los ajustes en la variable manipulada, por lo que reciben la denominación genérica de *controladores con restricciones*. A diferencia de los controladores de mínima varianza, estos son menos sensibles a errores en la modelización del modelo ARMAX utilizado para su diseño. Algunos tipos de controladores con restricciones se comentan a continuación.

Un grupo son los denominados controladores cuadrático-lineales a infinitos pasos, que minimizan la siguiente función objetivo:

$$\min_{x_1, x_2, \dots, x_N} \lim_{N \rightarrow \infty} E \left[\frac{1}{N} \left\{ \sum_{t=1}^N (Y_{t+f} - T)^2 + r(\nabla^d X_t)^2 \right\} \right] \quad [11]$$

donde el parámetro de restricción en los ajustes r actúa como un multiplicador de Lagrange en el proceso de optimización, y ∇^d es el filtro a aplicar para corregir la no estacionariedad del ruido N_t . La expresión (11) puede expresarse en forma equivalente como:

$$\min_{x_t} \{ \text{Var}(Y_t) + r \text{Var}(\nabla^d X_t) \}$$

donde se observa que se trata de minimizar la varianza del *output* sujeta a restricciones en la varianza de los ajustes del *input*. A este tipo de controladores se les suele denominar controladores de mínima varianza con restricciones (MVR). Si el proceso es invertible, haciendo $r=0$ se obtiene el controlador de mínima varianza. Sin embargo, si el proceso no es invertible, $r=0$ proporciona el esquema de regulación que minimiza la varianza del *output* condicionada a que la varianza de los ajustes sea finita. El problema de estos controladores es que su solución es complicada, requiriendo la utilización de ecuaciones de Wiener-Hopf discretas (Harris *et al.* 1980).

Clarke y Hasting-James (1971) y Clarke y Gawthrop (1975) proponen una alternativa mucho más sencilla de obtener controladores con restricciones mediante la minimización de la expresión:

$$\min_{x_t} \{ (Y_{t+f/t}^* - T)^2 + r(\nabla^d X_t)^2 \} \quad [12]$$

donde $Y_{t+f/t}^*$ es la predicción de varianza mínima del *output* Y_{t+f} hecha en el instante t . Este criterio es equivalente a minimizar la expresión:

$$\min_{x_t} E \{ (Y_{t+f} - T)^2 + r(\nabla^d X_t)^2 / Y_t, Y_{t-1}, \dots, X_{t-1}, X_{t-2}, \dots \} \quad [13]$$

que es equivalente a [11] haciendo $N=1$, por lo que el controlador de Clarke es un caso particular del controlador cuadrático-lineal general, en concreto es el controlador cuadrático-lineal óptimo a un paso. Este algoritmo determina en cada instante de tiempo t el ajuste a aplicar en el *input*, $\nabla^d X_t$, para conseguir que la predicción del *output* $Y_{t+f/t}^*$ coincida con su nominal T , sujeto a la restricción en la magnitud de

dicho ajuste en t , $\nabla^d X_t$, independientemente de los ajustes pasados o futuros. Algunos autores denominan este tipo de controlador como de *cortas miras*, puesto que en la determinación del ajuste a aplicar en cada instante de tiempo no tiene en cuenta el efecto que éste tendrá en el *output* en tiempos superiores al retardo del proceso f .

El criterio de Clarke (que conduce a los controladores cuadrático-lineales óptimos a un paso) es muy utilizado en la práctica dado que su solución es muy sencilla de obtener analíticamente y, para un mismo valor en la restricción de la varianza de los ajustes, provoca únicamente ligeros incrementos en la varianza del *output* respecto a los controladores de mínima varianza con restricciones (MacGregor y Tidwell 1977). Otro atractivo de este criterio es que conduce a controladores en los que el parámetro de restricción de los ajustes r aparece explícitamente en la ecuación del controlador (algo que no ocurre en los controladores de mínima varianza con restricciones), por lo que puede ser fácilmente modificado o autoajustado *on-line*.

Otro grupo de controladores con restricciones lo constituyen los *controladores de horizonte extendido* (*Extended Horizon Controllers*, EHC). Estos controladores son una modificación de los de mínima varianza [4] en los que la función objetivo a minimizar es:

$$\min. (Y_{t+m/t}^* - T)^2 \quad ; \quad m > f. \quad [14]$$

Estos controladores, en vez de conseguir que $Y_{t+f/t}^* = T$, como en el caso de los controladores de mínima varianza, determinan la acción de control en t para que $Y_{t+m/t}^* = T$, donde $m > f$. Esto provoca una disminución de la varianza de los ajustes (respecto al controlador de mínima varianza), al tiempo que incrementa su robustez frente a errores en el modelo. Capilla *et al.* (1999) derivan diversos controladores según los criterios anteriores obteniendo que el controlador de horizonte extendido (EHC) es un caso particular del controlador de Clarke para un cierto valor del coeficiente de restricción de los ajustes r .

En el caso en que los costes de muestreo y de ajuste no se consideren despreciables (lo que puede ocurrir en industrias de piezas, dado que los ajustes del proceso pueden suponer parada de máquinas, cambio de piezas y pérdida de productividad), los esquemas anteriores de ajuste no se deben aplicar en cada intervalo de muestreo, ya que la estrategia óptima dependerá de los costes relativos asociados a no fabricar en el objetivo frente a los de ajustar el proceso. Box (1991), Box y Kramer (1992), Box *et al.* (1994), Box y Luceño (1994, 1997a) y Luceño (1998) estudian en estos contextos lo que denominan esquemas óptimos

de ajuste acotado (*dead band feedback adjustment schemes*, también llamados *bounded schemes*).

3.3. Sistemas mono-input/mono-output

Ferrer *et al.* (1997) exponen la filosofía de la estrategia ESPC en el caso más sencillo de un sistema mono-input/mono-output (sistema SISO, *single-input/single-output*). En el desarrollo de la componente EPC, el conocimiento del modelo AR-MAX del proceso permite determinar las acciones de control a adoptar en cada instante t para minimizar la variabilidad de la característica de calidad en torno a su valor nominal.

El desarrollo de los esquemas de monitorización plantea varias cuestiones: como “qué monitorizar”, y “con qué herramienta”. La respuesta a estas cuestiones no es fácil, pues las causas especiales se manifiestan de forma diferente según el algoritmo de control utilizado, y la herramienta de monitorización más adecuada para detectar una causa especial depende de la forma en que dicha causa se manifieste. Stanfelj *et al.* (1991) presentan un método jerárquico basado en análisis de funciones de autocorrelación y correlación cruzada para evaluar el comportamiento de sistemas regulados y ayudar al diagnóstico de problemas relacionados fundamentalmente con errores de especificación del modelo, o con mal ajuste de los controladores. La monitorización de las desviaciones del *output* permite evaluar si el algoritmo de control está funcionando adecuadamente. Aunque para esto es necesario además monitorizar los ajustes en la variable manipulada, pues puede ocurrir que el sistema esté sometido a cambios que fuercen al controlador a realizar ajustes cada vez mayores que, si no se detectan a tiempo, pueden provocar la saturación del controlador y la imposibilidad de seguir compensando los efectos de estas causas especiales de variabilidad, generando problemas en el proceso. Algunas causas especiales que produzcan desviaciones temporales del modelo bajo control se pueden manifestar como datos anómalos o pautas inusuales en la secuencia de errores de predicción, por lo que es adecuado monitorizar dichos errores. También puede aportar información valiosa la monitorización de la serie de desviaciones del *output* reconstruidas en el supuesto de que no hubiera existido algoritmo de control.

Los procedimientos de monitorización consisten fundamentalmente en la aplicación de los gráficos de control estándar a las magnitudes resultantes del proceso regulado (errores de predicción, ajustes en las variables compensatorias, desviaciones del *output*, desviaciones del *output* reconstruidas para el caso en que no hubiera habido ajustes compensatorios, etc.). Para determinar qué tipo de gráfico es adecuado en cada caso, es necesario conocer la estructura de las diferentes

magnitudes a monitorizar bajo el sistema regulado, lo que puede obtenerse analíticamente a partir del modelo ARMAX y el algoritmo de control utilizado.

Si la dinámica del proceso ARMAX es $Y_t = H(B)X_t + N_t$, es posible expresar las acciones de control óptimo como $\nabla X_t = G(B)Y_t$. Sustituyendo esta ecuación en la anterior se puede obtener el modelo ARMA para las desviaciones del *output* respecto al nominal, $Y_t = A(B)a_t$. A partir de este modelo, sustituyendo en la ecuación de control, se obtiene el modelo ARMA para los ajustes de la variable compensatoria, $\nabla X_t = G(B)A(B)a_t$. Adicionalmente, en la deducción de la ecuación de control, se deriva el modelo ARMA para los errores de predicción (diferencia entre el *output* observado en t y el que se predijo para t en el instante $t-f$, siendo f el retardo de la función de transferencia).

Estos resultados son necesarios para el diseño de los procedimientos de monitorización. El conocimiento de la dinámica de estas variables permite modificar los parámetros del gráfico correspondiente (límites de control, señales de falta de control a emplear, etc.) con el fin de evitar la elevada frecuencia de falsas alarmas y la pérdida de potencia que supone utilizar gráficos de control estándar con datos autocorrelacionados (Capilla *et al.* 1999; Ferrer *et al.* 1998; Ferrer *et al.* 2000).

Capilla *et al.* (1999) y Ferrer *et al.* (1998) desarrollan en un proceso industrial petroquímico la nueva estrategia ESPC aplicada al control del índice de fluidez de un polímero mediante ajustes en la temperatura del reactor. Los autores diseñan varios tipos de algoritmos de control (mínima varianza, con restricciones, etc.) (Box *et al.* 1994; Bergh y MacGregor 1987; Harris y MacGregor 1987) estudiando su estabilidad y robustez frente a errores de especificación del modelo. Comparan el funcionamiento del sistema EPC frente al enfoque integrado EPC/SPC ante diversas causas especiales de variabilidad (error de medida del índice de fluidez del polímero en laboratorio, fallo de calibración del sensor de temperatura, presencia de contaminación en el flujo de entrada al reactor, cambios en las condiciones de activación del catalizador, ...) y obtienen que los controladores diseñados, en general, son bastante efectivos en la estabilización del proceso tras la presencia de las causas especiales de variabilidad. A pesar de ello, la varianza del sistema EPC aumenta respecto a la situación sin causas especiales. Esto es debido a que los controladores tardan un tiempo en cancelar el efecto de las perturbaciones, tiempo en el que la variabilidad del proceso aumenta. Los autores muestran cómo la incorporación de la componente SPC, para monitorizar el sistema, puede proporcionar a largo plazo una importante reducción de variabilidad de la característica de calidad, al permitir detectar las causas especiales y ayudar en su identificación, permitiendo la implantación de medidas correctoras que eviten su reaparición en el futuro.

3.4. Sistemas bi-input/mono-output

Martín *et al.* (1997) y Martín *et al.* (1998) amplían el estudio desarrollado por Capilla *et al.* (1999) al caso del control del índice de fluidez de un polímero mediante ajustes en dos variables compensatorias fácilmente manipulables: la temperatura del reactor y el caudal de entrada en el mismo de un producto químico (monómero).

Considerando el principio de superposición de modelos lineales, y que las dos variables de ajuste están incorrelacionadas, se puede añadir el efecto individual que cada variable compensatoria tiene sobre la variable respuesta, teniendo en cuenta que las perturbaciones pueden ser ajustadas mediante un único modelo de serie temporal. En este caso, se asume que el modelo ARMAX de causas comunes puede expresarse como:

$$Y_t = \left[\frac{\omega_1(B)B^{f_1}}{\delta_1(B)} X_{1,t} + \frac{\omega_2(B)B^{f_2}}{\delta_2(B)} X_{2,t} \right] + \frac{\theta_q(B)}{\Phi_p(B) \cdot \nabla^d} a_t$$

Los autores citados desarrollan diversas estrategias de control a partir de las ya comentadas en el apartado 3.2, pero particularizándolas al caso de dos variables de ajuste, y estudian sus propiedades de robustez frente a errores de especificación de los parámetros de la función de transferencia del modelo. Al mismo tiempo derivan la estructura de las diversas magnitudes resultantes de la regulación (desviación del *output*, ajustes, etc.)

El análisis de los resultados obtenidos bajo control refleja que los algoritmos de control bi-input permiten reducir todavía más la variabilidad del *output* respecto al control con una sola variable de ajuste (mono-input).

Se estudia también en estos trabajos la eficacia del sistema EPC ante diversas causas especiales de variabilidad. En los resultados obtenidos se observa que el controlador bi-input es preferible al mono-input en el sentido de que da lugar a errores cuadráticos medios en el *output* menores, y al mismo tiempo con menores ajustes en las variables compensatorias.

En todos los casos, las causas especiales empeoran el funcionamiento del proceso (incrementan el error cuadrático medio del *output*), pues los controladores tardan un tiempo en compensar sus efectos. Por ello, los autores estudian las ventajas del esquema integrado EPC/SPC mediante la monitorización de diversas magnitudes del proceso regulado, concluyendo que el esquema integrado ESPC es preferible al EPC al permitir detectar con rapidez la presencia de las causas especiales simuladas, lo que en la práctica permitirá investigarlas e implantar

medidas que eviten su aparición en el futuro, con la consiguiente mejora del proceso.

4. CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN

De la descripción de la metodología EPC/SPC y de las investigaciones industriales referenciadas en la bibliografía se concluye que es posible reducir sustancialmente la variabilidad de las características de calidad tanto a corto plazo como a largo plazo, lo que permite tanto la optimización como la mejora continua de la calidad. De este modo se hace viable el control de procesos dinámicos, mejorando su capacidad, reduciendo las falsas alarmas y aumentando la escasa potencia que se tiene cuando se usan las técnicas tradicionales de SPC en estos contextos. Recurriendo a un ejemplo práctico se puede decir que “no se puede conducir un vehículo con SPC, pero tampoco se puede detectar un fallo en el sistema de dirección del vehículo con EPC” (Faltin *et al.* 1993). Pero quizá ambas cosas son posibles con un sistema integrado EPC/SPC.

Un tema que merece ser investigado con mayor profundidad es la forma de implantar los esquemas EPC en la práctica: utilizando una estructura de controlador ya prefijada que funcione razonablemente bien en un amplio rango de situaciones, o diseñando el algoritmo de control a partir del modelo ARMAX y de la función objetivo a minimizar.

Algunos autores como Box y Kramer (1992) sugieren utilizar directamente la estructura del controlador PI (proporcional-integral) (10) expresado como:

$$X_t = -k_p e_t - k_i \sum_{i=0}^t e_i$$

donde los coeficientes del término proporcional (k_p) e integral (k_i) pueden ajustarse mediante técnicas de experimentación secuencial (*Evolutionary Operations*, EVOP) (Box y Draper 1968) que permiten experimentar en condiciones de producción normal (experimentación *on-line*). Box y Luceño (1997b) proporcionan un estudio muy exhaustivo de estos esquemas PI comparando su funcionamiento con otros esquemas óptimos de regulación más complejos. Las ventajas que ofrecen estos controladores PI son su sencillez (los ajustes en cada instante t se calculan como combinación lineal de las dos últimas desviaciones del *output*) y facilidad de implantación (los ajustes pueden obtenerse gráficamente). Tsung *et al.* (1998) estudian la eficiencia y robustez de los controladores PI ante diversas dinámicas de proceso y modelos de ruido (ARMA(1,1) y ARIMA(1,1,1)). Los autores recomiendan el uso en la práctica de estos controladores, dada su relativa poca pérdida de

eficiencia respecto al controlador de mínima varianza en un rango amplio de valores de los parámetros del modelo, y su robustez frente a errores de especificación en el mismo. En el caso en que sea necesario utilizar controladores con restricciones, Box y Luceño (1995) también sugieren la utilización de controladores PI con los parámetros adecuadamente ajustados, y comparan su buen funcionamiento relativo a los esquemas óptimos en estas situaciones (controladores de mínima varianza con restricciones, expresión [11]), mucho más complicados de obtener.

Otros autores como Vander Wiel y Vardeman (1992) consideran, sin embargo, que aunque el controlador PI puede ser adecuado en muchas situaciones, es conveniente derivar el algoritmo de control a partir de la identificación y estimación del modelo ARMAX del sistema. Una ventaja de este método es que se pueden obtener analíticamente los modelos que seguirán las diversas magnitudes resultantes del sistema regulado (desviaciones del *output*, ajustes, etc.), y se pueden diseñar los esquemas de monitorización adecuados según su estructura (Capilla *et al.* 1999).

Un peligro que tiene este enfoque es que, puesto que el modelo de perturbaciones N_t se identifica y estima a partir de datos históricos del proceso, en ocasiones puede ocurrir que un modelo no estacionario IMA(1,1) se estime equivocadamente como un modelo estacionario ARMA (1,1) con parámetro ϕ cercano a uno, siendo ambos modelos equivalentes desde el punto de vista estadístico (Ferrer *et al.* 2000). El problema de este error de modelización del ruido es que el algoritmo de control derivado bajo la suposición del modelo de perturbaciones estacionario ARMA, en presencia de perturbaciones no estacionarias IMA, provocaría un controlador inestable (ajustes cada vez mayores) que forzaría a la desconexión del controlador automático y a una pérdida de confianza en el sistema EPC por parte de los operarios e ingenieros del proceso. Esto también podría ocurrir en el caso en que el modelo de perturbaciones, inicialmente estacionario, hubiera cambiado a un proceso no estacionario. Esta falta de robustez de los controladores diseñados suponiendo modelos ARMA para las perturbaciones, ante perturbaciones no estacionarias, ha sido estudiada por varios autores (Box y Luceño 1997a; Ferrer *et al.* 2000; Tsung *et al.* 1998).

Sin embargo, el modelo IMA es robusto a errores de especificación en el sentido de que el controlador diseñado según este modelo no estacionario, en presencia de ruido estacionario, seguiría siendo estable y sólo daría lugar a un incremento en la varianza del *output*. La robustez del modelo IMA para las perturbaciones N_t , en contraste con el modelo ARMA, se explica fundamentalmente porque el modelo no estacionario fuerza a la ecuación de control a incluir una acción integral pura, que es capaz de compensar cambios de nivel (Box y Luceño 1997a; Ferrer *et al.* 2000; Tsung *et al.* 1998).

El modelo IMA, por tanto, aparte de ser una alternativa más segura frente a errores de especificación del modelo, debido a su no estacionariedad, constituye un modelo más creíble frente al modelo ARMA estacionario, ya que este último asume que si el sistema funciona en ciclo abierto (sin ajustes de control) el *output* continuará fluctuando alrededor de su nominal sin experimentar cambios de nivel, lo que resulta una hipótesis poco realista en muchos contextos industriales.

Las ventajas del modelo IMA frente a otros modelos de perturbaciones estacionarios no invalida la estrategia de diseño de los algoritmos de control a partir de la modelización del sistema dinámico, sino que es un elemento más a tener en cuenta en el proceso de diseño. Por otra parte, los controladores con restricciones derivados a partir del criterio de Clarke (expresiones [12] y [13]) pueden llegar a ser incluso más sencillos de obtener que los controladores PI con restricciones (Box y Luceño 1995). Además, el hecho de tener explícito en la ecuación de control el parámetro de restricción de los ajustes r puede resultar interesante desde el punto de vista de la estrategia ESPC por la posibilidad de desarrollar esquemas de control con parámetro de restricción variable. Así, ante determinadas señales de falta de control detectadas por los diferentes gráficos monitorizados, se podría tratar de reducir el peso del coeficiente r para permitir acciones de control más agresivas que corrigieran el proceso en menos tiempo. Habría que estudiar, sin embargo, ante qué tipo de situaciones causantes de ciertas salidas de control estadístico del proceso, este esquema sería efectivo, ya que, por ejemplo, ante cambios en la dinámica del ruido o de la función de transferencia, una disminución del peso del coeficiente r supondría una disminución en la robustez del controlador, lo que podría ocasionar problemas de inestabilidad en la práctica (Capilla *et al.* 1999; Ferrer *et al.* 1998).

Estas cuestiones siguen siendo objeto de debate actual en la comunidad científica y continuarán siéndolo en el futuro, por lo que estudios comparativos de los diferentes enfoques planteados podrían aportar luz sobre esta problemática.

Otro tema abierto es cómo desarrollar la metodología ESPC en procesos multi-*input*/multi-*output* (sistemas MIMO) donde existen varias variables *output* relacionadas entre sí (v.g. distintas variables de calidad, variables de productividad, etc.), que pueden depender de más de un parámetro de proceso (*inputs*). El diseño de sistemas de regulación automática (componente EPC) ha sido tratado en el contexto MIMO por algunos autores (Harris y MacGregor 1987). La aplicación de la metodología ESPC en este contexto, supone integrar el sistema de regulación con otro de monitorización, basado en la detección de *outliers* en funciones de transferencia múltiples, tema poco tratado en la bibliografía existente sobre estas cuestiones.

REFERENCIAS

- ALWAN, A.J.; ALWAN, L.C. (1994). «Monitoring Autocorrelated Processes Using Multivariate Quality Control Charts». *Proceedings of the Decision Sciences Institute Annual Meeting* 3, 2106-2108.
- ALWAN, L.C. (1992). «Effects of Autocorrelation on Control Chart Performance». *Communications in Statistics – Theory and Methods* 21, 1025-1049.
- ALWAN, L.C.; ROBERTS, H.V. (1988). «Time Series Modeling for Statistical Process Control». *Journal of Business & Economic Statistics* 6, (1), 87-95.
- APLEY, D.W.; TSUNG, F. (2002). «The Autoregressive T^2 Chart for Monitoring Univariate Autocorrelated Processes». *Journal of Quality Technology* 34, (1), 80-96.
- BAGSHAW, M.; JOHNSON, R.A. (1975). «The Effect of Serial Correlation on the Performance of CUSUM Tests II». *Technometrics* 17, 73-80.
- BARNARD, G.A. (1959). «Control Charts and Stochastic Processes». *Journal of the Royal Statistical Society, Series B*, 21, (2), 239-271.
- BERGH, L.G.; MACGREGOR, J.F. (1987). «Constrained Minimum Variance Controllers: Internal Model Structure and Robustness Properties». *Industrial and Engineering Chemistry Research* 26, 1558-1564.
- BERTHOUEX, P.M.; HUNTER, W.H.; PALLESEN, L. (1978). «Monitoring Sewage Treatment Plants: Some Quality Control Aspects». *Journal of Quality Technology* 10, (4), 139-149.
- BOX, G.E.P. (1991). «Bounded Adjustment Charts». *Quality Engineering* 4, 143-151.
- BOX, G.E.P.; COLEMAN, D.E.; BAXLEY, R.V., JR. (1997). «A comparison of Statistical Process Control and Engineering Process Control». *Journal of Quality Technology* 29, (2), 128-130.
- BOX, G.E.P.; DRAPER, N.R. (1968). *Evolutionary Operation*, New York, Wiley.
- BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C. (1994). *Time Series Analysis: Forecasting and Control* (3rd ed.), New Jersey, Prentice Hall.
- BOX, G.E.P.; KRAMER, T. (1992). «Statistical Process Monitoring and Feedback Adjustment - A Discussion». *Technometrics* 34, 251-285.
- BOX, G.E.P.; LUCEÑO, A. (1994). «Selection of Sampling Interval and Action Limit for Discrete Feedback Adjustment». *Technometrics* 36, 369-378.

- BOX, G.E.P.; LUCEÑO, A. (1995). «Discrete Proportional-Integral Control With Constrained Adjustment». *Journal of the Royal Statistical Society D - The Statistician* 44, (4), 479-495.
- BOX, G.E.P.; LUCEÑO, A. (1997a). *Statistical Control by Monitoring and Feedback Adjustment*, New York, Wiley.
- BOX, G.E.P.; LUCEÑO, A. (1997b). «Discrete Proportional-Integral Adjustment and Statistical Process Control». *Journal of Quality Technology* 29, (3), 248-260.
- BOX, G.E.P.; MACGREGOR, J.F. (1974). «The Analysis of Closed-Loop Dynamic-Stochastic Systems». *Technometrics* 16, 391-398.
- BOX, G.E.P.; RAMIREZ, J. G. (1992). «Cumulative Score Charts». *Quality and Reliability Engineering International* 8, 17-27.
- CAPILLA, C. (1991). «Aportaciones al conocimiento de las propiedades estadísticas de los gráficos de control para la media» *Tesis doctoral*. Universidad Politécnica de Valencia.
- CAPILLA, C.; FERRER, A.; ROMERO, R.; HUALDA, A. (1999). «Integration of Statistical an Engineering Process Control in a Continuous Polymerization Process». *Technometrics* 41, (1), 14-28.
- CLARKE, D.W.; GAWTHROP, B.A. (1975). «Self-tuning controller». *Proc. Institution of Electrical Engineers* 122, 929-934.
- CLARKE, D.W.; HASTING-JAMES, R. (1971). «Design of digital controllers for randomly disturbed systems». *Proc. Institution of Electrical Engineers* 118, 1503-1506.
- CONSTABLE, G.K.; YEN, V. (1991). «Autocorrelation and Control». *ASQC Quality Congress Transactions*, Milwaukee, WI, (EE.UU.), 375-382.
- FALTIN, F.W.; HAHN, G.J.; TUCKER, W.T.; VANDER WIEL, S.A. (1993). «Algorithmic Statistical Process Control: Some Practical Observations». *International Statistical Review* 61, 67-80.
- FALTIN, F.W.; MASTRANGELO, C.M.; RUNGER, G.C.; RYAN, T.P. 1997). «Considerations in the Monitoring of Autocorrelated and Independent Data». *Journal of Quality Technology* 29, (2), 131-133.
- FERRER, A.; BARCELÓ, S.; HERMENEGILDO, F. (2000). «Engineering Statistical Process Control (ESPC) in a Tile Industry». *Proceedings of the Industrial Statistics in Action 2000 International Conference*, University of Newcastle upon Tyne, Newcastle, (Reino Unido), 145-158.

- FERRER, A.; CAPILLA, C.; ROMERO, R.; MARTIN, J. (1998). «Developing Optimal Regulation and Monitoring Strategies to Control a Continuous Petrochemical Process». *Quality Improvement Through Statistical Methods*, Bovas Abraham Ed., Birkhäuser, Boston, MA, (EE.UU.), 61-77.
- FERRER, A.; ROMERO, R.; ZÚNICA, L.; CAPILLA, C. (1997). «Monitorización estadística de procesos regulados». *XXIII Congreso Nacional de Estadística e I.O.*, Valencia (España), 10:7-10:8.
- GOLDSMITH, P.L.; WHITFIELD, H. (1961). «Average Run Lengths in Cumulative Chart Quality Control Schemes». *Technometrics* 13, 11-20.
- HARRIS, T.J.; MACGREGOR, J.F. (1987). «Design of Multivariable Linear-Quadratic Controllers Using Transfer Functions». *AIChE Journal* 33, 1481-1495.
- HARRIS, T.J.; MACGREGOR, J.F.; WRIGHT, J.D. (1980). «Self-Tuning and Adaptive Controllers: An Application to Catalytic Reactor Control». *Technometrics* 22, 153-164.
- HARRIS, T.J.; ROSS, W.H. (1991). «Statistical Process Control Procedures for Correlated Observations». *The Canadian Journal of Chemical Engineering* 69, 48-57.
- HOERL, R.W.; PALM, A.C. (1997). Discussion of «Statistical Process Monitoring and Feedback Adjustment – A Discussion» por G.E.P. Box y T. Kramer. *Technometrics* 34, (3), 268-272.
- HUNTER, J.S. (1986). «The Exponentially Weighted Moving Average». *Journal of Quality Technology* 18, (4), 203-210.
- ISERMANN, R. (1981). *Digital Control Systems*, Berlin, Springer-Verlag.
- JANAKIRAM, M.; KEATS, J.B. (1998). «Combining SPC and EPC in a Hybrid Industry». *Journal of Quality Technology* 30, (3), 189-200.
- JOHNSON, R.A.; BAGSHAW, M., (1974). «The Effect of Serial Correlation on the Performance of CUSUM Tests». *Technometrics* 16, 103-112.
- KEATS, J.B.; HUBELE, N.F. (Eds.) (1991). *Statistical Process Control in Automated Manufacturing*, Nueva York, Marcel Dekker.
- KEATS, J.B.; MONTGOMERY, D.C. (Eds.) (1991). *Statistical Process Control in Manufacturing*, Nueva York, Marcel Dekker.
- LIN, W.S.W.; ADAMS, B.M. (1996). «Combined Control Charts for Forecast-Based Monitoring Schemes». *Journal of Quality Technology* 28, (3), 289-301.

- LU, C.W.; REYNOLDS, M.R., JR. (1999a). «EWMA Control Charts for Monitoring the Mean of Autocorrelated Processes». *Journal of Quality Technology* 31, (2), 166-188.
- LU, C.W.; REYNOLDS, M.R., JR. (1999b). «Control Charts for Monitoring the Mean and Variance of Autocorrelated Processes». *Journal of Quality Technology* 31, (3), 259-274.
- LUCEÑO, A. (1998). «Performance of Discrete Feedback Adjustment Schemes With Dead Band, Under Stationary Versus Nonstationary Stochastic Disturbance». *Technometrics* 40, (3), 223-233.
- MACGREGOR, J.F. (1988). «On-Line Statistical Process Control». *Chemical Engineering Progress* 84, 21-31.
- MACGREGOR, J.F. (1991). Discussion of «Some Statistical Process Control Methods for Autocorrelated Data» por D.C. Montgomery y C.M. Mastrangelo. *Journal of Quality Technology* 23, (3), 198-199.
- MACGREGOR, J.F. (1992). Discussion of «Statistical Process Monitoring y Feedback Adjustment - A Discussion» por G.E.P. Box y T. Kramer. *Technometrics* 34, 273-275.
- MACGREGOR, J.F.; HARRIS, T.J. (1990). Discussion of «Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements» por J.M. Lucas y M.S. Saccucci. *Technometrics* 32, 1-29.
- MACGREGOR, J.F.; TIDWELL, P.W. (1977). «Discrete Stochastic Control With Input Constraints». *Proc. Institution of Electrical Engineers* 124, 732-734.
- MACGREGOR, J.F.; TIDWELL, P.W. (1980). «Modeling and Control of Continuous Industrial Polymerization Reactors». *American Chemical Society Symp. Ser. 124, Computer Applications to Chemical Engineering*, R.G. Squires and G.V. Reklaitis (Eds.).
- MARTÍN, J.; CAPILLA, C.; FERRER, A.; ROMERO, R. (1997). «Aplicación de un controlador *bi-input* a un proceso industrial continuo». *XXIII Congreso Nacional de Estadística e I.O.*, Valencia (España), 11:7-11:8.
- MARTÍN, J.; FERRER, A.; CAPILLA, C.; ROMERO, R. (1998). «Análisis del comportamiento de un controlador *bi-input* en un proceso industrial continuo cuando se producen causas especiales». *XXIV Congreso Nacional de Estadística e I.O.*, Almería (España), 45-46.

- MESSINA, W.S.; MONTGOMERY, D.C.; KEATS, J.B.; RUNGER, G.C. (1996). «Strategies for Statistical Monitoring of Integral Control for the Continuous Process Industries» en *Statistical Applications in Process Control*, J.B. Keats y D.C. Montgomery (Eds.), Nueva York, Marcel Dekker, 193-215.
- MONTGOMERY, D.C. (2001). *Introduction to Statistical Quality Control*, Nueva York, Wiley.
- MONTGOMERY, D.C.; KEATS, B.J.; RUNGER, G.C.; MESSINA, W.S. (1994). «Integrating Statistical Process Control and Engineering Process Control». *Journal of Quality Technology* 26, (2), 79-87.
- MONTGOMERY, D.C.; MASTRANGELO, C.M. (1991). «Some Statistical Process Control Methods for Autocorrelated Data». *Journal of Quality Technology* 23, (3), 179-204.
- NEMBARD, H.B.; MASTRANGELO, C.M. (1998). «Integrated Process Control for Startup Operations». *Journal of Quality Technology* 30, (3), 201-210.
- PADGETT, C.S.; THOMB, L.A.; PADGETT, W.J. (1992). «On the α -risks for Shewhart Control Charts». *Communications in Statistics – Simulation and Computation* 21, 1125-1147.
- PAGE, E.S. (1954). «Continuous Inspection Schemes». *Biometrika* 41, 100-115.
- PAGE, E.S. (1961). «Cumulative Sum Charts». *Technometrics* 3, (1), 1-9.
- PALM, A.C. (1990). «SPC Versus Automatic Process Control». *ASQC Quality Congress Transactions*, San Francisco, (EE.UU.), 694-699.
- ROBERTS, S.W. (1959). «Control Chart Tests Based on Geometric Moving Averages». *Technometrics* 1, 239-250.
- ROMERO, R. (2000). «Calidad Total, Estadística y Método Científico». *Real Academia de Cultura Valenciana – Discursos nº 35*, Valencia, (España).
- RUNGER, G.C.; WILLEMAIN, T.R.; PRABHU, S. (1995). «Average Run Lengths for CUSUM Control Charts Applied to Residuals». *Communications in Statistics – Theory and Methods* 24, 273-282.
- SHEWHART, W.A. (1931). *Economic Control of Quality of Manufactured Product*, Nueva York, D.Van Nostrand Co., Inc.
- STANFELJ, N.; MARTIN, T.E.; MACGREGOR, J.F. (1991). «Monitoring and Diagnosing Process Control Performance: The Single Loop Case». *Proceedings of the American Control Conference*, IEEE, Boston, MA, (EE.UU.), 2886-2892.

- SUPERVILLE, C.R.; ADAMS, B.M. (1994). «An Evaluation of Forecast-Based Quality Control Schemes». *Communications in Statistics – Simulation and Computation* 23, 645-661.
- TSUNG, F.; WU, H.; NAIR, V.N. (1998). «On the Efficiency and Robustness of Discrete Proportional-Integral Control Schemes». *Technometrics* 40, (3), 214-222.
- TUCKER, W.T. (1992). «Discussion of Statistical Process Monitoring and Feedback Adjustment - A Discussion». *Technometrics* 34, 275-277.
- TUCKER, W.T.; FALTIN, F.W.; VANDER WIEL, S.A. (1993). «Algorithmic Statistical Process Control: An Elaboration». *Technometrics* 35, 363-375.
- VANBRACKLE, L.N.; REYNOLDS, M.R., JR. (1997). «EWMA and CUSUM Control Charts in the Presence of Correlation». *Communications in Statistics – Simulation and Computation* 26, 979-1008.
- VANDER WIEL, S.A. (1996). «Modelling Processes That Wander Using Moving Average Models». *Technometrics* 38, 139-151.
- VANDER WIEL, S.A.; TUCKER, W.T.; FALTIN, F.W.; DOGANAKSOY, N. (1992). «Algorithmic Statistical Process Control: Concepts and an Application». *Tecnometrics* 34, 286-297.
- VANDER WIEL, S.A.; VARDEMAN, S.B. (1992). Discussion of «Statistical Process Monitoring and Feedback Adjustment - A Discussion» por G.E.P. Box y T. Kramer. *Technometrics* 34, (3), 278-281.
- VASILOPOULOS, A.V.; STAMBOULIS, A.P. (1978). «Modification of Control Chart Limits in the Presence of Data Correlation». *Journal of Quality Technology* 10, 20-30.
- WARDELL, D.G.; MOSKOWITZ, H.; PLANTE, R.D. (1994). «Run Length Distributions of Special-Cause Control Charts for Correlated Processes». *Technometrics* 36, 3-17.
- WOODALL, W.H.; MONTGOMERY, D.C. (1999). «Research Issues and Ideas in Statistical Process Control». *Journal of Quality Technology* 31, (4), 376-386.
- ZHANG, N.F. (1998). «A Statistical Control Chart for Stationary Process Data». *Technometrics* 40, 24-38.

STATISTICAL PROCESS CONTROL IN PROCESSES WITH DYNAMICS: REVIEW OF THE STATE OF THE ART AND FUTURE PERSPECTIVES

SUMMARY

In this paper a review of the state of the art on the application of Statistical Process Control (SPC) in processes with dynamics is presented. Nowadays, this type of processes are very common in modern highly automated environments of both parts and process industry. In these contexts autocorrelation is part of the common-cause system. Firstly, a review of the monitoring strategies developed to adapt standard control charts to processes with inertial components is presented. Secondly, the combined strategy ESPC (*Engineering Statistical Process Control*), integration of SPC with Control Theory (*Engineering Process Control*, EPC), is introduced. ESPC uses the valuable information hidden in process dynamics and the existence of readily adjustable compensatory variables to improve process control. Several successful real applications of ESPC are illustrated. Finally, some open research fields are outlined.

Key words: ARIMAX models; Autocorrelation; Control charts; Constrained controllers; Statistical process monitoring; Process regulation.

AMS Classification: 62M10; 62N10; 93A25; 93B30; 93B52